ORGANISATION MONDIALE DE LA PROPRIETE INTELLECTUELLE Bureau international



DEMANDE INTERNATIONALE PUBLIEE EN VERTU DU TRAITE DE COOPERATION EN MATIERE DE BREVETS (PCT)

(51) Classification internationale des brevets 6 : G06T 5/00

(11) Numéro de publication internationale:

WO 99/405

(21) Numéro de la demande internationale:

(43) Date de publication internationale:

12 août 1999 (12.08.99)

(22) Date de dépôt international:

PCT/FR99/00176

28 janvier 1999 (28.01.99)

(30) Données relatives à la priorité:

98/01308

4 février 1998 (04.02.98)

FR

A1

(71) Déposant (pour tous les Etats désignés sauf US): UNIVERSITE PIERRE ET MARIE CURIE (PARIS VI) [FR/FR]; 4, place Jussieu, F-75252 Paris Cedex 05 (FR).

(72) Inventeurs; et

- (75) Inventeurs/Déposants (US seulement): FAUDEMAY, Pascal [FR/FR]; 33, rue Saint-Amand, F-75015 Paris (FR). DU-RAND, Gwenael [FR/FR]; 4, rue Dussoubs, F-75002 Paris
- (74) Mandataires: GUTMANN, Emest etc.; Emest Gutmann-Yves Plasseraud S.A., 3, rue Chauvau-Lagarde, F-75008 Paris

(81) Etats désignés: BR, CA, IL, IN, JP, US, brevet européen (AT, BE, CH, CY, DE, DK, ES, FI, FR, GB, GR, IE, IT, LU, MC, NL, PT, SE).

Publiée

Avec rapport de recherche internationale. Avant l'expiration du délai prévu pour la modification des revendications, sera republiée si des modifications sont

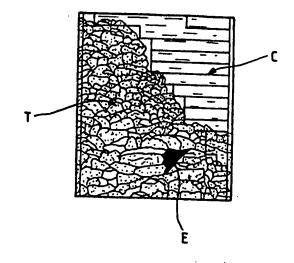
- (54) Title: METHOD FOR SPATIAL SEGMENTATION OF AN IMAGE INTO VISUAL OBJECTS AND APPLICATION
- (54) Titre: PROCEDE DE SEGMENTATION SPATIALE D'UNE IMAGE EN OBJETS VISUELS ET APPLICATION

(57) Abstract

The invention concerns a method for spatial segmentation of images into visual objects to obtain objects having semantic significance comprising steps which consists in dividing the image into initial regions, fusing the neighbouring initial regions according to certain similarity functions and obtaining enlarged images, then repeating said phase with the remaining initial regions and the enlarged regions until there is no possibility of further fusion. The invention also concerns the use of said method for characterising, classifying, storing, detecting objects, scenes, planes, groups of planes, movements, in multimedia documents, particularly of video.

(57) Abrégé

L'invention porte sur un procédé de segmentation spatiale d'images en objets visuels pour obtenir des objets ayant une signification sémantique comportant des étapes de partition d'images en régions initiales, de fusion de régions initiales voisines selon certaines fonctions de similarité et l'obtention de régions élargies, puis une itération de cette phase avec les régions initiales restantes et les régions élargies jusqu'à ce qu'aucune fusion ne soit plus possible. L'invention porte également sur l'utilisation du procédé à la caractérisation, à la classification, au stockage, à la détection d'objets, de scènes, de plans, de groupes de plans, de mouvements, dans des documents multimédia en particulier de vidéo.



UNIQUEMENT A TITRE D'INFORMATION

Codes utilisés pour identifier les Etats parties au PCT, sur les pages de couverture des brochures publiant des demandes internationales en vertu du PCT.

AL AM AT AU AZ BA BB BF BG BJ BR BY CA CF CG CH CI CM CU CZ DE DK EE	Albanie Armenie Autriche Australie Azerbaldjan Bosnie-Herzégovine Barbade Belgique Burkina Faso Bulgarie Bénin Brésil Bélarus Canada République centrafricaine Congo Suisse Côte d'Ivoire Cameroun Chine Cuba République tchèque Allemagne Danemark Estonie	ES FI FR GA GB GE GR HU IE IL IS IT JP KE KG KP LC LL LK LR	Espagne Finlande France Gabon Royaume-Uni Géorgie Ghana Guinée Grèce Hongrie Irlande Israël Islande Italie Japon Kenya Kirghizistan République populaire démocratique de Corée République de Corée	LS LT LU LV MC MD MG MK MN MN MN MN NE NL NO NZ PL PT RO RU SD SE SG	Lesotho Lituanie Luxembourg Lettonie Monaco République de Moldova Madagascar Ex-République yougoslave de Macédoine Mali Mongolie Mauritanie Malawi Mexique Niger Pays-Bas Norvège Nouvelle-Zélande Pologne Portugal Roumanie Fédération de Russie Soudan Suède Singapour	SI SK SN SZ TTD TG TJ TM TT UA UG US VN YU ZW	Slovénie Slovaquie Sénégal Swaziland Tchad Togo Tadjikistan Turkménistan Turquie Trinité-et-Tobago Ukraine Ouganda Etats-Unis d'Amérique Ouzbékistan Viet Nam Yougoslavie Zimbabwe
--	---	---	--	--	--	---	--

15

20

30

PROCEDE DE SEGMENTATION SPATIALE D'UNE IMAGE EN OBJETS VISUELS ET APPLICATION

L'invention concerne le domaine de l'analyse de l'information contenue dans les images couleur, provenant notamment de documents multimédias, et en particulier de vidéos. Cette analyse est destinée plus particulièrement, mais non exclusivement, à permettre une indexation de la documentation audiovisuelle.

Le problème consiste en particulier à réaliser un découpage temporel de séquences vidéos en scènes qui constituent des unités narratives de ces séquences, en vue du stockage et de la visualisation sélective de certaines scènes par les utilisateurs. Un tel niveau de compréhension n'est pas directement accessible par les méthodes de segmentation connues.

Des méthodes ont été développées pour réaliser la segmentation d'images de niveaux de gris ou pour la segmentation d'objets en mouvement dans les images d'une vidéo. Mais parmi les algorithmes de segmentation d'images couleur, aucun ne fournit de résultats suffisants lorsque les images à analyser sont tirées de la "vie réelle". Les principales méthodes peuvent être regroupées en méthodes de type pixels, de type contours, et de type régions.

Dans les méthodes de segmentation de type pixels, une région est définie comme une composante connexe d'un ensemble de pixels spécifié par une fonction d'appartenance, éventuellement floue, à une classe de couleur de l'Espace de Couleurs (en abrégé EdC). Ces méthodes se différencient principalement par la façon dont elles définissent les classes de couleurs et les fonctions d'appartenance à ces classes. La plus simple de ces méthodes est une quantification rigide de l'EdC, comme décrit dans les articles de C. Carson, S. Belongie, et al. "Region Based Image Querying", Proc. CVPR'97, Workshop on Content-Based Access of Image

15

20

25

30

and Video Libraries, 1997, et de J.R. Smith and S.-F. Chang. "Tools and Techniques for Color Image Retrieval.", Proc. SPIE'96, Storage & Retrieval for Image and Video Databases IV, Vol. 2670, 1996. Cependant certaines couleurs proches dans l'EdC peuvent se trouver dans des classes distinctes.

Une autre méthode de type pixel est une méthode par seuillage d'histogrammes, dans laquelle les pics et les creux apparaissant dans un ou plusieurs histogrammes correspondant aux différentes dimensions de l'EdC sont recherchés. Les creux détectés sont alors utilisés comme limites entre les classes de couleurs (comme décrit par exemple dans l'article de R. Hayasaka, J. Zhao and Y. Matsushita, "Outstanding Object-Oriented Color Image Segmentation Using Fuzzy Logic". Proc SPIE'97 Multimedia Storage and Archiving Systems II, Vol. 3229, 303-314, 1997.

Les méthodes de groupement (clustering en terminologie anglaise) de l'EdC sont des extensions multidimensionnelles des techniques précédentes de seuillage et appliquent des algorithmes de classification tels que les algorithmes de recherche de plus proches voisins, (cf. l'article de R. Ferri and E. Vidal, "Color Image Segmentation and labeling through multiediting and condensing", Pattern Recognition Letters, vol. 13, No. 8, pp. 561-568, 1992), l'algorithme de moyenne K (K-mean en terminologie anglaise) ou de moyenne floue C (Fuzzy c-mean en terminologie anglaise) (cf. l'article de Y.W. Lim, S.U. Lee, "On The Color Image Segmentation Algorithm Based on the Thresholding and the Fuzzy c-Means Techniques", Pattern Recognition, Volume 23, Number 9, pp. 935-952, 1990). Ces algorithmes permettent de rechercher des clusters potentiels de couleurs dans les images. Enfin certaines méthodes recherchent l'EdC permettant une représentation optimale des images à l'aide de techniques telles que l'analyse en composantes principales ou la transformée de Karhunen-Loève, telle que celle décrite dans l'article de S.E. Umbaugh et al, ``Automatic Color Segmentation Algorithm with Application to Skin Tumor

15

25

Feature Identification", IEEE Engineering in Medicine and Biology, Vol. 12, No. 3, pp. 75-82, 1993.).

Le premier inconvénient de ces méthodes est qu'une recherche robuste de pics dans les histogrammes ou de clusters dans l'EdC n'est pas aisée, en particulier dans le cas d'images peu contrastées, et peut être coûteuse en temps de calculs. De plus, ces méthodes considèrent implicitement que si deux pixels, c'est-à-dire deux points d'image homogène, que le support soit une image vidéo ou non, appartiennent à une même région de l'image, leurs couleurs respectives appartiennent à la même classe de couleurs ou sont proches dans l'EdC. Ceci ne s'applique correctement que dans des images de type "clip-arts" ou de dessins animés, mais généralement pas dans les images réelles complexes. Au moment de l'extraction des régions, ces méthodes doivent donc analyser le voisinage immédiat des pixels pour déterminer à quelle région chaque pixel doit être attaché.

Par ailleurs, dans les méthodes de type contours, les contours sont détectés et utilisés pour déterminer les limites des régions. Cependant, les méthodes d'extraction de contours ne sont pas des techniques de segmentation par elles-mêmes et doivent être combinées avec au moins une des autres méthodes. De plus les contours obtenus dans le cas d'images peu contrastées ou très texturées sont difficilement utilisables car ils ne sont généralement pas fermés.

Dans les algorithmes de type régions, une région est définie comme une ensemble de pixels connectés satisfaisant un critère d'homogénéité donné, par exemple une zone qui ne contient qu'une couleur présente dans 95% des pixels de la région. Dans les techniques dites de découpage et fusion (split-and-merge en terminologie anglaise), les régions non homogènes sont découpées en sous-régions, puis analysées de manière récursive jusqu'à ce que le critère d'homogénéité

soit satisfait pour chacune des régions obtenues. Les régions voisines ainsi obtenues sont regroupées.

Les techniques dites de croissance de régions (region-growing, en terminologie anglaise) sont des méthodes de type régions dans lesquelles un certain nombre de zones initiales, utilisées comme germes de croissance, sont d'abord recherchées. Les pixels et régions avoisinant(es) sont itérativement englobés à ces zones initiales jusqu'à ce qu'un critère d'arrêt soit satisfait, par exemple lorsque le nombre de régions obtenues est inférieur à un seuil.

10

15

20

Un exemple connu de cette catégorie de méthode est l'algorithme dit des "bassins topographiques" dans lequel une image est considérée comme un relief topographique, où l'altitude de chaque point peut, par exemple, être proportionnelle à son intensité lumineuse. Le fond des bassins les plus importants est percé, et le relief est plongé dans l'eau. Les bassins se remplissent progressivement, délimitant ainsi les principales régions. Cette méthode est très sensible aux bruits et coûteuse en temps de calcul. Une autre méthode de cette catégorie est la méthode basée sur les arbres couvrants récursifs de poids minimum (Recursive Shortest Spanning Trees, en anglais, RSST en abrégé). RSST (voir l'article de O.J. Morris et al, in « graph theory for image analysis: an approach based on RSST ». IEEE proceedings, vol. 1333, 146-152, 1986) considère chaque pixel comme une région initiale. Les régions dont les couleurs moyennes sont les plus proches sont fusionnées de manière récursive, en favorisant la fusion des régions de petites tailles.

25

La plupart des méthodes précédemment citées opèrent à l'échelle du pixel. Ceci les rend particulièrement sensibles aux variations locales d'intensité et donc aux textures.

Cette sensibilité est nécessaire pour les applications de vision artificielle ou de reconnaissance de formes pour lesquelles l'extraction des

15

20

contours exacts est primordiale, mais elle est pénalisante dans le cas de recherche de larges régions sémantiquement significatives.

L'invention vise à pallier ces inconvénients en proposant une segmentation en régions de tailles telles que les régions ainsi segmentées aient encore une signification sémantique dans le contexte de l'image. Par objet sémantique ou sémantiquement significatif, il est entendu un objet correspondant au monde réel, par exemple un visage, un ciel, etc. Plusieurs objets sémantiques peuvent composer un autre objet sémantique (par exemple une chevelure, un visage et une veste constituent une personne) ci-après appelé objet sémantique composite. Les objets sémantiques composant un objet sémantique composite peuvent aussi être eux-mêmes des objets sémantiques composites (par exemple le visage est composé, entre autres, d'un nez, d'une bouche et d'yeux).

L'utilisation d'une segmentation des images en objets ayant une valeur sémantique significative est une étape clé du procédé d'analyse et de compréhension du contenu des documents multimédias, en particulier des documents vidéo.

L'invention permet de segmenter les images en objets significatifs tout en négligeant les détails.

L'invention vise ainsi à obtenir une segmentation robuste en présence d'images éventuellement très texturées, et insensible aux détails non significatifs qui pourraient entraîner une sur-segmentation inutile de larges régions homogènes, par exemple une corde noire sur un mur blanc.

Pour ce faire, il est proposé de qualifier de détails à écarter les régions "non signifiantes" ayant une surface inférieure à un certain pourcentage de la surface totale de l'image (par exemple 1%) et de ne pas segmenter l'image en régions pouvant recouvrir plusieurs objets de façon à éviter sa sous-segmentation, pouvant conduire à des régions dépourvues de signification sémantique.

20

25

30

Le procédé de segmentation selon l'invention qui s'apparente aux techniques de type région, opère dans un premier temps à l'échelle de la région, en partant de blocs initiaux de taille réduite tout en étant considérés comme homogènes, de façon à permettre la segmentation de plus larges objets.

L'invention porte donc sur un procédé de segmentation spatiale d'une image en objets visuels, caractérisé en ce que, pour obtenir des objets ayant une signification sémantique, il comporte les étapes suivantes :

- dans une première phase, une partition de l'image en régions selon un pavage prédéterminé, une fusion de régions voisines dont la similarité, selon une première fonction de similarité, est inférieure à un premier seuil, et l'obtention de régions élargies,
 - dans une deuxième phase, une fusion d'une région élargie de taille inférieure à un deuxième seuil avec une région voisine qui lui est la plus similaire selon une deuxième fonction de similarité.

Avantageusement, le procédé selon l'invention comporte également une troisième phase de fusion des régions obtenues à l'issue de la deuxième phase et qui sont similaires selon une troisième fonction de similarité.

Dans les différentes phases du procédé de segmentation selon l'invention, les fonctions de similarité utilisées sont différentes dans au moins deux des phases.

Plus précisément, l'invention a pour objet un procédé de segmentation spatiale d'une image en objets visuels qui, pour obtenir des objets ayant une signification sémantique, comporte les étapes suivantes :

- dans une première phase, une partition de l'image en régions initiales selon un pavage prédéterminé, et une fusion des régions voisines dont la similarité est inférieure à un premier seuil, selon une fonction de similarité connue entre régions ;

20

25

30

- dans une deuxième phase, une fusion des régions de taille inférieure à un deuxième seuil avec la région voisine la plus similaire ; et

- dans une troisième phase, une représentation de chacune des régions obtenues par un nuage de points dans un espace de représentation formé d'au moins une dimension de base caractérisant un signal électromagnétique provenant de cette région et d'une dimension caractérisant les pixels correspondant aux valeurs considérées dans les autres dimensions, avec

- un ajustement polynomial d'une courbe avec les points représentant chaque pixel de la région dans l'espace de représentation du signal électromagnétique ;
- une représentation de chaque ajustement polynomial par une suite de valeurs :
- l'application d'une fonction de similarité entre les deux suites de
 valeurs ainsi définies, et
 - la fusion des régions voisines dont la proximité entre les ajustements polynomiaux est inférieure à un troisième seuil.

Dans le procédé de l'invention, les régions voisines fusionnables dans chacune des phases peuvent être des régions initiales, des régions issues d'une fusion de régions initiales, ou des régions élargies issues de fusions précédentes; les différents types de régions ainsi définies sont fusionnables entre elles à partir du moment où on leur applique la même fonction de similarité, et jusqu'à ce que toutes les similarités selon la fonction appliquée soient supérieures au seuil choisi.

Quand, dans la phase suivante, une nouvelle fonction de similarité est appliquée, la fusion des régions obtenues dans une phase précédente par application d'une fonction de similarité à seuil moins élevé est alors possible jusqu'à ce qu'aucune fusion ne soit plus possible.

Le processus peut être ainsi réitéré par application d'une nouvelle fonction de similarité à seuil plus élevé que la précédente. Les régions

10

15

20

fusionnables restent toujours celles qui n'ont pas fusionné au seuil moins élevé de la fonction précédente, et ce y compris des régions initiales.

De plus, la fonction de similarité entre deux régions peut être définie par la position des centroïdes des deux régions et des extrémités des deux segments de courbe représentant ces deux régions.

De la même façon, le signal électromagnétique apparaissant dans au moins deux images peut être transformé pour en extraire au moins deux composantes de mouvement entre les deux images pour le représenter, telles que valeur scalaire et orientation, les autres étapes du procédé s'appliquant à cette représentation.

Dans le procédé selon l'invention, les points d'un nuage décrivant une région sont distribués dans un espace dont trois dimensions de base sont trois combinaisons linéaires ou non linéaires distinctes des trois couleurs primaires de la synthèse additive, et une autre dimension dans cet espace étant l'effectif des pixels selon cette distribution.

Dans un autre mode de réalisation, les points d'un nuage décrivant une région sont distribués dans un espace dont trois dimensions de base sont la teinte, la saturation et l'intensité de la couleur et une autre dimension dans cet espace étant l'effectif des pixels selon cette distribution.

Dans ce cas, le calcul de similarité entre régions est réalisé :

- en utilisant l'espace teinte/saturation/intensité si une saturation moyenne est supérieure à un quatrième seuil prédéterminé ;
- dans l'espace des intensités, si la saturation est inférieure ou égale à ce quatrième seuil.

Selon un autre aspect de l'invention, une seconde segmentation à une échelle plus fine, qui peut être celle du pixel est réalisée de façon à obtenir les contours précis des limites des objets, ainsi que leur structure

15

20

25

interne, puis une fusion des deux segmentations est réalisée afin d'obtenir à la fois des objets sémantiquement significatifs et des contours précis pour ces objets.

Par une mise en oeuvre du même algorithme à deux échelles de résolution différentes, les résultats des deux segmentations des deux premières étapes sont cohérents et peuvent se combiner.

Ainsi l'invention concerne également un procédé de segmentation fine d'images en objets sémantiquement significatifs, consistant :

- dans un premier temps, à extraire de l'image les régions homogènes en couleur et en texture correspondant aux objets présents, en négligeant les objets de petites tailles inférieures à un seuil défini en pourcentage de la surface de l'image, et en utilisant une représentation des régions par ajustement polynomial de leur distribution de couleurs dans un espace des couleurs (EdC), à la fois lors de la segmentation et en représentation finale des objets segmentés,
- à réitérer l'extraction avec une résolution plus fine, afin de préciser les contours, les régions obtenues correspondant alors à des parties d'objets,
- dans une troisième étape, une superposition des deux segmentations précédentes fournit des régions correspondant aux objets de l'image de la première étape avec les contours précis de la deuxième étape, ainsi qu'une structure interne représentative de ces objets.

Par structure interne, on entend que l'image est représentée comme une arborescence d'objets, chaque objet de niveau supérieur pouvant inclure un ou plusieurs objets de niveau inférieur.

Les deux dernières étapes peuvent naturellement être réalisées à plusieurs résolutions consécutives de façon à obtenir une description hiérarchique de la structure des objets sémantiques composites.

Préférentiellement, le calcul de similarité entre régions peut être réalisé :

15

25

- selon le procédé de l'invention si la saturation, considérée comme critère de superposition, est supérieure à un quatrième seuil prédéterminé ;
- dans l'espace teinte-saturation-intensité, si la saturation est inférieure ou égale à ce seuil ;

les seuils prédéterminés peuvent être choisis pour maintenir le nombre de régions dans un intervalle dans lequel la sur-segmentation et la sous-segmentation n'apparaissent pas et pour maintenir la distribution des tailles des régions dans un intervalle défini pour éviter la sur et la sous-segmentation.

Les paramètres de seuil, de degré de polynôme et de fonction de similarité peuvent être choisis de façon adaptative par une méthode d'apprentissage prédéterminée, en fonction de seuils de sur- et de sous-segmentation à éviter, et d'un calcul d'évaluation prédéterminé de celles-ci.

De manière générale, la fonction de similarité appliquée à l'issue quelconque des étapes du procédé inclut le paramètre de seuil au-delà duquel la fusion n'est pas réalisée.

Avantageusement, des utilisations composites du procédé selon 20 l'invention sont mises en oeuvre :

- avec la reconnaissance d'un locuteur, pour caractériser le contenu des plans et des scènes d'une vidéo :
- avec un alignement automatique entre le script et la vidéo, pour caractériser le contenu des plans et des scènes d'un document vidéo ou pour apprendre de façon automatique les caractéristiques des objets présents dans la vidéo et dans le script.

D'autres caractéristiques et utilisations de l'invention ressortiront de la description qui suit de modes de réalisation détaillés, accompagnés des figures annexés qui représentent respectivement :

20

25

- la figure 1, un exemple d'image obtenue à l'issue de l'application des deux premières phases de segmentation large du procédé selon l'invention ;

- les figures 2a et 2b, une représentation des régions d'une image dans l'espace RVB (Rouge, Vert, Bleu) par des nuages de points et des courbes d'ajustement;
- la figure 3, les projections d'un nuage de points de l'espace RVB sur le plan (RB) et le plan (RV) pour déterminer les extrémités de l'intervalle d'ajustement ;
- la figure 4, la distribution des distances euclidiennes des points à leurs droites respectives pour des keyframes (images caractéristiques) et des images fixes;
 - les figures 5a et 5b, 6a et 6b, 7a et 7b, la segmentation en objets sémantiques sur trois images (5), (6), (7), respectivement à la fin de la deuxième phase du procédé (figures 5a, 6a et 7a) et à la fin de la troisième phase (respectivement figures 5b, 6b et 7b);
 - les figures 8a et 8b, respectivement une segmentation dite large, obtenue avec une résolution de 16x16 pixels, et une résolution dite fine, de 4x4 pixels, sur une même image ; et
 - la figure 9, une superposition des segmentations large et fine précédemment obtenues.

L'invention est d'abord décrite comme un algorithme de la segmentation de larges régions. La segmentation fine est un mode plus particulier pouvant être réalisé par le même algorithme. Un algorithme utilisant deux résolutions, et combinant les deux segmentations obtenues, est décrit plus loin.

Selon un premier exemple de réalisation, l'image est d'abord découpée en une grille de blocs dits initiaux, de taille adaptée, égale à 0,25% de la surface de l'image courante, c'est-à-dire :

10

15

20

25

30

- suffisamment petits pour que les objets de taille supérieure à un seuil (1% dans l'exemple de réalisation), en dessous duquel ils sont considérés comme des détails, soient segmentés, et

- suffisamment larges pour limiter les temps de calcul, qui augmentent de manière « surlinéaire » avec le nombre de blocs initiaux.

A partir de ce découpage, un histogramme des couleurs de chaque bloc initial est calculé dans l'espace RVB (Rouge Vert Bleu). Ce calcul consiste à comptabiliser le nombre de pixels ayant chacune des couleurs (des 256 couleurs dans l'exemple de réalisation) apparaissant dans l'image, chaque couleur étant la valeur prise par l'une des coordonnées de l'espace RVB.

Dans la première phase de fusion, chaque région est évaluée par un calcul de distance entre son histogramme et ceux des régions adjacentes. Les calculs des distances sont réalisés selon la norme d'ordre 1 (L1), égale à la somme des valeurs absolues des différences au 1er degré des valeurs des histogrammes prises deux par deux, les normes d'ordre n, (Ln), étant celles de Minkowski (égales à la puissance 1/n de la somme des valeurs absolues des mêmes différences à la puissance n).

La région courante est fusionnée avec celle dont l'histogramme est le plus proche du sien, mais uniquement si la distance qui sépare leurs histogrammes est inférieure à un seuil élevé qui, dans cet exemple de réalisation, est fixé à 50% de la distance maximale possible de cet exemple de réalisation. Plus le seuil est élevé, plus le niveau de similarité des régions fusionnées est élevé. La fusion est réitérée jusqu'à ce que toutes les distances entre régions adjacentes soient supérieures à ce seuil.

A la fin de cette première phase, les régions restantes sont soit des petites régions, c'est-à-dire correspondant à des détails (taille inférieure à 1% dans l'exemple de réalisation), soit des régions plus larges et homogènes, du fait du seuil de fusion élevé (50% dans l'exemple de réalisation). Ces larges régions peuvent éventuellement être très

15

20

25

texturées, c'est-à-dire avec une granularité de texture de l'ordre de la taille des blocs initiaux.

La première phase est suivie d'une deuxième phase de fusion des seules petites régions, de taille inférieure à 1% dans l'exemple de réalisation. Ces "détails" sont fusionnés automatiquement avec leur plus proche voisine par suppression du seuil de fusion de 50 % utilisé lors de la première phase, de sorte que tous les détails sont intégrés à leur région englobante ou à leur plus proche voisine.

A ce point de l'algorithme, un graphe de régions larges et homogènes est obtenu, correspondant à de larges parties d'objets situés dans l'image, et contenant éventuellement les détails intégrés lors de la deuxième phase. La figure 1 montre le résultat de la segmentation à la fin de la deuxième phase. Le tumulus représenté T a été fusionné malgré la granularité importante de la texture de cette région grâce à l'utilisation d'une taille de blocs initiaux (1 %) de l'ordre de grandeur du grain de la texture.

L'entrée E du tumulus étant plus petite que le seuil de 1% dans l'exemple de réalisation, elle a été segmentée lors de la première phase, puis a été fusionnée lors de la deuxième phase puisque, évaluée comme détail, elle ne pouvait pas être considérée comme un objet sémantique significatif par le présent algorithme.

Ainsi, en partant de blocs initiaux de taille suffisamment importante, des comparaisons de distribution de couleurs et non des comparaisons de couleurs sont réalisées, ce qui rend l'algorithme insensible aux textures de granularité de l'ordre de celle des blocs initiaux.

En revanche, le ciel C qui est composé d'un dégradé progressif de plus de 50 variations de bleus est dit sur-segmenté car, étant a priori un objet sémantiquement unique, on devait s'attendre à une segmentation unique pour ne former qu'une seule région.

20

25

30

Des objets, comme le ciel de cette figure 1, peuvent être sursegmentés, les régions qui les composent restant « perceptuellement » similaires. La troisième phase permet de dépasser ce stade.

La sur-segmentation du ciel C illustre les limites de l'utilisation des histogrammes de couleurs : ils sont sensibles aux effets optiques tels que l'illumination. les variations d'éclairage ou les dégradés, comme décrit dans l'article de M. Stricker and M. Orengo, "Similarity of Color Images", Proc. SPIE'95, Storage & Retrieval for Image and Video Databases III, 1995). De plus, comme les régions sont homogènes, leurs histogrammes correspondants sont "creux" (c'est-à-dire présentent une proportion importante de valeurs proches ou égales à 0) et ne peuvent donc être efficacement comparés à l'aide des mesures de distances telles que L1 ou L2.

Une autre représentation des régions est donc réalisée dans une troisième phase, afin de permettre non seulement de comparer les distributions de couleurs, mais aussi les couleurs dans l'EdC (Espace des Couleurs).

Une représentation des régions d'une image dans l'espace RVB (Rouge, Vert, Bleu) est illustrée aux figures 2a et 2b.

Sur la figure 2a, chaque région est représentée par la moyenne statistique des valeurs de son histogramme formant sa couleur moyenne, correspondant au centroïde C de chaque nuage de points N1 à N6, correspondant aux distributions de couleurs des régions, et par un intervalle polynomial, P, qui donne une estimation des variations de couleurs au sein de la région.

Les distributions des couleurs qui présentent une forte corrélation ont une forme curviligne, ce qui justifie l'estimation de ces région par un ajustement polynomial, avec un intervalle de domaine de définition du polynôme. La figure 2b représente les nuages de points correspondants à la distribution des couleurs apparaissant dans l'image composée de 3

15

20

25

30

régions sémantiques principales R1 à R3, ainsi qu'une courbe C1 (en pointillés) correspondant à l'estimation polynomiale de la région R1.

A la fin de la deuxième phase, les nuages des régions obtenus sont des sous-ensembles, ou sous-régions, des régions finales R1 à R3. Dans le cas présent, 6 sous-régions N1 à N6 ont été extraites. Un ajustement polynomial est calculé pour les régions finales, ainsi qu'un intervalle sur leur domaine de définition. Dans le cas idéal, le polynôme P d'une région finale et ceux Pi des sous-régions (obtenues en fin de deuxième phase) qui la composent, sont les mêmes. Et l'intervalle de P est l'union des intervalles des Pi.

La troisième phase de l'algorithme fusionne les régions dont les ajustement polynomiaux sont similaires, et ayant des intervalles sur le domaine de définition similaires, consécutifs, ou se chevauchant.

En pratique, pour limiter le nombre de calculs à réaliser, une droite est approximée en utilisant la méthode classique de régression linéaire. Dans le présent exemple de réalisation de l'algorithme, les nuages de points des régions obtenues (Figure 2b) à la fin de la deuxième phase sont alors représenté par un segment de droite obtenu par un ajustement linéaire et par le centroïde du nuage N1 à N6 correspondant, qui n'est pas nécessairement le centre du segment.

Chacune des régions est représentée par sa couleur moyenne et par un segment S1 à S6 de droite porté par la droite de régression linéaire du nuage de points correspondant (figure 2b).

Pour chaque région, tel qu'illustré sur la figure 3, le nuage de points de coordonnées (r,v,b) de l'espace RVB est projeté en N(r,b) sur le plan (RB) ainsi qu'en N(r,v) sur le plan (RV). Dans ces plans, nous calculons respectivement les droites de régression linéaire de b en r, notée D1 sur la figure, et de v en r, notée D2. Les deux droites obtenues sont les projections sur les deux plans (RB) et (RV) de la droite cherchée, notée D3.

10

15

20

25

Les extrémités E1 et E2 du segment de droite représentatif S sont les projections sur la droite de régression D3 des points extrêmes du nuage de points N. Dans ces conditions, le segment ne va pas au-delà de la projection des points les plus extrêmes du nuage de points.

Pour éviter que la longueur du segment ne soit influencée de façon importante par la présence de couleurs provenant par exemple de détails, la distance euclidienne de ces extrémités au centroïde du nuage est de préférence limitée à un seuil dans l'espace RVB, seuil égal à 1,5 fois l'écart type de la distribution des couleurs pour la région considérée dans l'exemple de réalisation.

Une telle estimation des distributions des couleurs des régions dans l'EdC par un ajustement linéaire a été testée en mesurant les coefficients de régression linéaire obtenus lors des ajustements, ainsi que la longueur des segments obtenus et la distance euclidienne moyenne des points à leurs droites respectives. Ces mesures sont réalisées sur une collection de 4000 images caractéristiques (keyframes en terminologie anglaise) extraites de 4 films, et une collection d'environ 1000 images fixes obtenues sur les sites du réseau internet.

Les coefficients de régression moyens obtenus sont égaux à 0,87 pour les keyframes et à 0,84 pour les images fixes.

La distribution des distances euclidiennes des points à leurs droites respectives est représentée sur la figure 4. Pour les keyframes K, respectivement les images fixes F, la distance moyenne est de 3,17, respectivement 4,88, pour une longueur moyenne de segment de 74,63, respectivement 90,5.

Ces résultats montrent une forte corrélation linéaire entre les couleurs présentes dans les régions, qui justifie la représentation par approximation polynomiale adoptée dans le présent algorithme.

10

15

La fusion des régions lors de la troisième phase de l'algorithme est réalisée en comparant non plus les histogrammes de couleurs, mais les segments représentatifs obtenus à la deuxième étape.

La comparaison des segments est réalisée dans l'espace Teinte-Saturation-Intensité HSI (initiales de « Hue-Saturation-Intensity » en terminologie anglaise). Cet espace est perceptuellement uniforme, car fournissant une représentation linéaire des variations de fréquence spectrale d'une couleur, alors que l'espace RVB, ne fournissant pas une telle représentation, n'est pas adapté à une telle comparaison.

Cette comparaison exploite le fait que les variations de Teinte et de Saturation dans les régions sont faibles, alors que les variations d'intensité sont importantes. Les variations moyennes observées sur toutes les régions extraites de toutes les images des collections précédentes sont présentées dans le tableau 1. Les variations de teintes sont exprimées en degrés, les autres paramètres en distance euclidienne dans l'espace RVB.

Teinte Saturation Intensité Keyframes 15.17

9.56 41.76 images 20.97 18.35 48.48

-- TABLEAU 1 --

20 Pour limiter, lors de la troisième étape, la fusion aux régions perceptuellement similaires, et donc appartenant potentiellement aux mêmes objets de la scène, seules les régions dont les différences de Teinte et de Saturation entre les centroïdes sont inférieures à un seuil donné sont fusionnés. 25

Dans l'exemple de réalisation, la différence maximale de teinte est fixée à un seuil égal à 7,5°, et la différence maximale de saturation à un seuil de 15%. Comme représenté sur l'exemple de la figure 3, les régions voisines R1, R2 et R3, satisfaisant ces critères sont fusionnées. Ces

15

20

segments représentatifs sont proches du meilleur ajustement polynomial, pouvant être obtenu dans le cas d'un ajustement d'ordre supérieur à un.

Lorsque la saturation moyenne est faible, par exemple inférieure à environ 7% de la saturation maximale, la notion de teinte n'est plus représentative et les segments sont alors uniquement comparés sur la base de leur intensité moyenne et de leur variation en intensité. Ce cas correspond aux couleurs "proches" des gris. Ainsi, la méthode de comparaison consiste principalement à comparer les niveaux de gris moyens (i.e. l'intensité moyenne) et les variations en intensité (i.e. les textures).

Cette méthode de comparaison est une approximation d'une mesure de similarité entre ajustements polynomiaux, mais est néanmoins valide puisque le coefficient de corrélation linéaire au sein des nuages de points correspondant aux régions est élevé.

Les figures suivantes présentent la segmentation Σ en objets sémantiques sur trois images (5), (6), (7), respectivement à la fin de la deuxième phase du procédé (figures 5a, 6a et 7a) et à la fin de la troisième phase (respectivement figures 5b, 6b et 7b).

Il apparaît que la fusion des régions similaires, obtenue lors de la troisième étape, fournit une segmentation réaliste des images (5), (6), (7).

Un autre mode de réalisation concerne la segmentation fine d'objets obtenus à l'aide du procédé de fusion précédent, visant à obtenir le contour fin de ces objets ainsi que leur structure interne. Le même algorithme est utilisé avec au moins deux résolutions différentes, l'une dite fine et l'autre dite large. Cette résolution plus fine est obtenue uniquement en utilisant des blocs initiaux de taille plus petite, par exemple 4x4 pixels. L'algorithme réalise alors la segmentation en découpant à l'échelle du pixel, ce qui la rend plus sensible aux contours et aux textures.

Contrairement aux méthodes de l'état de la technique évoquées plus haut, même lors de la segmentation fine, les zones dont la surface

15

20

25

représente moins d'une valeur seuil, fixée à 1% dans l'exemple de réalisation dans l'exemple de réalisation, de la surface de l'image ne sont pas prises en compte. Cela permet en particulier d'extraire les petits objets qui n'auraient pas été détectés par la première segmentation du fait de la résolution plus importante. Les figures 8a et 8b présentent respectivement une segmentation dite large Σ , obtenue avec une résolution de 16x16 pixels, et une résolution dite fine Σ f de 4x4 pixels, sur une même image.

Puis une superposition permet d'obtenir une segmentation finale optimisée Σ o, telle que représentée en figure 9 ; les deux segmentations sont obtenues à l'aide du même algorithme avec, comme paramètre d'entrée relatif à la résolution, 4 X 4 pixels et 16 X 16 pixels.

La superposition conserve les contours 10 des régions fines incluses dans les régions ayant une signification sémantique. Cependant, les régions fines peuvent ne pas être systématiquement incluses dans la région large correspondante, car pouvant résulter de détails obtenus grâce à la résolution plus fine, par exemple les barres 11 sur le mur à l'arrière du personnage de la figure 9.

Pour plus de clarté, nous utilisons le terme de région pour désigner les larges régions sémantiquement significatives obtenues par une segmentation avec de larges blocs initiaux, et le terme de zones pour désigner les régions fines obtenues avec de petits blocs. Le résultat final (figure 9) est obtenu par la superposition des deux résultats intermédiaires. Dans le cas idéal, chaque région serait composée exactement (au contour près) de l'ensemble des zones qu'elle contient spatialement.

Trois cas peuvent cependant se présenter :

• Une zone est spatialement incluse dans une région et sa représentation est proche (au sens de la mesure de similarité utilisée lors de la troisième phase de l'algorithme de base) de celle de cette région. Dans ce cas, on considère que la zone fait partie de la région.

25

30

- Du fait de la résolution plus précise de la segmentation fine, une zone peut correspondre à un détail de l'image n'ayant pas été extrait par la segmentation grossière (ex : les barres 11 sur le mur à l'arrière du personnage de la figure 9). Dans ce cas la distance entre les représentations de la zone et de la région est élevée, et on considère que la zone ne fait pas partie de la région, mais forme une région par ellemême. Ces zones peuvent éventuellement être utilisées pour l'étude de la structure spatiale des régions.
- Une zone n'est pas majoritairement incluse dans une région (en pratique, un seuil dépendant de la taille de la zone est fixé) mais s'étend sur plusieurs régions (ex : le col 12 de la chemise du personnage de la figure 9). Dans ce cas, la zone fait partie de la région la plus similaire, ou est considérée comme région à part entière si aucune des régions avoisinantes n'est assez similaire.

Des exemples d'application du procédé selon l'invention sont décrits ci-après.

Exemple 1 : Caractérisation des objets; classification.

L'ensemble des caractéristiques des objets segmentés est conservé en vue d'une analyse du document et/ou d'une indexation des images pour permettre la recherche de plans sur leur contenu en terme d'objets sémantiques et d'actions de ces objets. L'ensemble des caractéristiques de chaque région (couleur, texture, taille, position, indice de forme, mouvement,...) est très compact. Dans le cas d'un ajustement linéaire, un résumé des caractéristiques précédentes peut être stockés dans moins de 20 octets (La position de la couleur moyenne et du segment représentatif en nécessitant 9). Des représentations plus complètes peuvent nécessiter quelques dizaines d'octets par objet.

Une image peut être représentée sous une forme résumée par une liste de descripteurs des principaux objets qu'elle contient, chaque descripteur incluant notamment la position et le mouvement de l'objet. Les

15

20

25

30

critères de choix des principaux objets peuvent être par exemple la taille, la différence de couleur avec les objets voisins, le mouvement, ou des connaissances sémantiques du type "l'objet X est important". Sur la base d'une représentation de 4 objets dans une image, par exemple, la représentation de l'image peut être aussi compacte que 80 octets. Pour caractériser un objet, il est utile de connaître non seulement le descripteur de cet objet, mais également les descripteurs des objets voisins, puisqu'un objets peut aussi être caractérisé par son contexte (ex : un avion dans le ciel.).

La sémantique de certains des objets segmentés par la méthode proposée peut être aisément extraite à l'aide de leurs caractéristiques visuelles dans un certain nombre de cas simples (ex : détection de ciels de jours, d'éclairages, de peau, ...). Cependant, l'association d'une sémantique aux objets peut également s'appuyer sur l'apport de connaissances externes. Par exemple : "un ciel est un objet bleu ou gris peu texturé, en général en haut d'une image".

Le problème de la caractérisation d'un objet sémantique est un problème connu de classification ou de groupement (clustering) de points dans un espace multi-dimensionnel. Cette classification peut s'effectuer avec ou sans apprentissage, en mode supervisé ou non. Dans le procédé du présent brevet, cette classification s'appuie sur une représentation compacte de l'objet et le cas échéant des objets environnants, dans un espace multi-dimensionnel.

Les méthodes connues de classification qui peuvent être utilisées sont les méthodes classiques d'analyse des données, les méthodes neuronales et les méthodes par algorithmes génétiques.

Dans certaines méthodes d'analyse des données, les nuages de points voisins sont caractérisés comme des clusters et projetés dans un espace de représentation plus petit adéquat. La caractérisation des objets du cluster peut alors se faire à partir de la description par l'utilisateur d'un

15

20

25

ou plusieurs objets du cluster. Le système d'indexation généralise la caractérisation d'un ou plusieurs objets décrits par des points du cluster, à des objets décrits par d'autres points de ce cluster.

Dans l'approche neuronale, le système apprend un « classifieur », qui permet de diviser l'espace de représentation en clusters, à partir d'un ensemble d'exemples. Les exemples peuvent être fournis par un des utilisateurs du système pendant l'apprentissage ou en cours d'utilisation.

Dans l'approche génétique, il existe un ensemble de classifieurs initiaux, caractérisés chacun par une fonction de similarité prise dans un ensemble de fonctions possibles, et par des seuils. Ces classifieurs sont représentés par une signature qui est une chaîne de bits. Les classifieurs initiaux peuvent être tirés au hasard ou fournis par des utilisateurs. L'utilisateur ou le système détermine quels classifieurs ont donné une réponse appropriée. Les classifieurs qui ont participé aux bonnes réponses sont hybridés par recombinaison de la signature de deux de ces classifieurs. Des modifications aléatoires des signatures ou "mutations", peuvent également être appliquées lors de la création de nouveaux classifieurs. Pour certaines classes d'applications, ce processus converge vers une population de classifieurs proche de l'optimum.

La quatrième méthode de classification envisageable à partir de la segmentation de l'image en objets sémantiques, est la recherche d'objets visuels similaires à un ensemble d'exemples donnés, à partir d'une similarité des caractéristiques de couleurs, de formes, etc. La requête initiale obtient une fonction globale de similarité, en calculant une somme de fonctions de similarité appliquées indépendamment à différents critères, chacune étant pondérée par une valeur appelée poids. Cette requête initiale peut être enrichie de façon connue en permettant à l'utilisateur de spécifier quels sont les réponses satisfaisantes ou non. Une technique générique d'enrichissement d'une requête vectorielle à partir de ces réponses est connue. Dans certaines variantes de cette technique, elle

20

25

30

peut s'appuyer sur l'estimation des modifications souhaitables des poids des différentes fonctions de similarité, par des méthodes dérivées des probabilités bayésiennes. La recherche vectorielle par similarité est proposée par plusieurs projet d'indexation de la vidéo, mais ces projets ne s'appuient pas sur une segmentation spatiale des objet sémantiques et une mesure de similarité selon notre procédé.

Selon la présente approche, l'application de ces méthodes est facilitée par la taille réduite du descripteur, et par la possibilité pour l'utilisateur d'indiquer des exemples et des contre-exemples, et le cas échéant d'indiquer si la réponse est satisfaisante ou non.

Un script décrivant le contenu de chaque plan d'une vidéo est aligné sur les limites de plans de la vidéo par des méthodes connues. Ce script décrit chaque objet d'un plan et ses actions. En corrélant la présence d'un objet dans le script et dans la vidéo, il est possible de déterminer avec une certaine probabilité quel objet de la vidéo correspond à un objet du script et quelles sont ses actions. A partir de cette information, on dispose d'exemples de ce type d'objet, qui permettent de construire automatiquement un classifieur pour cet obiet.

Une autre utilisation de ces méthodes dans notre procédé est d'utiliser la segmentation pour annoter les objets par des caractéristiques objectives ou subjectives. Pour reconnaître la présence d'une de ces caractéristiques dans un objet ou une partie d'une vidéo, il est possible de choisir de façon automatique comme exemples les objets visuels qui sont annotés par cette caractéristique, et de procéder ensuite à l'apprentissage d'un des classifieurs précédents.

Dans le cas particulier ou l'objet correspond à un personnage, la reconnaissance du locuteur par des méthodes connues d'analyse audio permet de choisir comme exemple plusieurs instances d'un même objet, et de procéder ensuite à l'apprentissage des caractéristiques de cet objets selon l'une des méthodes mentionnées précédemment.

Dans tous les cas, la segmentation et la classification des objets d'une scène et de leur mouvement permet de générer un script de la scène qui décrit les objets, les actions, et l'ambiance de la scène.

Exemple 2 : Segmentation temporelle de vidéo en séguences

De façon connue, une vidéo est le plus souvent structurée en plans, séparés par des coupures (cuts en anglais) ou par des effets spéciaux (fondus, volets). Un plan est une suite continue d'images effectué en une seule prise par une seule caméra. La segmentation d'une vidéo en plans est utile notamment pour naviguer dans la vidéo à partir d'un interface appelé "story-board", qui représente chaque plan par une image caractéristique.

Cependant, plusieurs plans peuvent avoir un contenu sémantique voisin, et d'autre part le nombre de plans dans une vidéo est souvent très élevé, ce qui est défavorable à une navigation efficace dans la vidéo à partir du story board.

Plusieurs auteurs ont proposé de représenter la vidéo en vue d'une description de son contenu et de la navigation dans ce contenu, comme une suite de séquences. Selon cette approche, une séquence est une suite de plans décrivant un même environnement et les mêmes personnages. La séquence est une unité sémantique appropriée pour la description de contenu et la navigation dans la vidéo.

Des méthodes pour la segmentation automatique d'une vidéo en séquences ont déjà été proposées. Par exemple, un changement dans l'évolution de la durée des plans peut caractériser un changement de séquences.

Une autre méthode de segmentation en séquences est basée sur la détection d'objets caractéristiques. Par exemple, un changement de séquence est souvent lié à un changement d'environnement, par exemple

20

25

30

entre intérieur / extérieur / jour / nuit. La détection d'un objet de type ciel de jour ou ciel de nuit ou éclairage permet éventuellement de caractériser un plan comme tourné en extérieur jour ou extérieur nuit.

Dans le procédé selon la présente invention, la segmentation en objets sémantiques puis la caractérisation d'un certain nombre d'objets par les méthodes du paragraphe précédent permet de détecter des limites de séquences.

Deux autres types d'intervalles temporels sont les groupes de plans (prises de vue, groupements) et les sujets. Les groupes de plans ont les mêmes propriétés que les séquences, mais ne sont pas formés nécessairement de plans contigus. Les sujets sont une suite de séquences portant sur un même thème. La détection de sujets est particulièrement intéressante pour caractériser des intervalles temporels dans des vidéos documentaires ou d'actualités.

La segmentation en sujets selon la présente application s'appuie sur la segmentation en séquences selon l'approche décrite précédemment. La détection d'une limite de sujet se fait à partir d'une ou plusieurs des méthodes suivantes :

- Une méthode syntaxique connue
- La présence d'un objet sémantique appartenant à une classe d'objets caractérisant un certain sujet
- L'extraction du texte des dialogues et des commentaires par des méthodes connues de dictée vocale, les mots de ces textes étant ensuite classés par concepts à l'aide d'une méthode telle que celle publiée auparavant par Dumais et Foltz (Comm. ACM).

Une fois la vidéo segmentée en sujets, la caractérisation du sujet par un ou plusieurs descripteurs s'appuie sur les mêmes méthodes.

Exemple 3 : Segmentation d'objets sémantiques composites

Les objets sémantiques composites sont composés d'une ou plusieurs régions sémantiques segmentées par la méthode décrite ci-

15

20

25

30

dessus. Dans la figure 8, le personnage est un objet sémantique composite composé du casque, du visage, de la veste, du col de chemise, ... Il est intéressant de pouvoir le retrouver par une région quelconque, par exemple par le casque, ou de visualiser et d'annoter le personnage complet et pas seulement le visage.

La segmentation de tels objets ne peut en général être réalisée uniquement à partir d'une image fixe.

Il est dans certain cas possible, par exemple lorsqu'une focale longue a été utilisée pour la prise de vue, de séparer les objets de l'avant plan qui sont nets, des objets de l'arrière plan qui sont susceptible d'être flous. Ce type de segmentation n'est cependant pas utilisable systématiquement, et est susceptible de conduire à des soussegmentations importantes (exemple : l'arrière plan segmenté comme un seul objet).

La segmentation des objets en mouvements peut aussi être utilisée pour la segmentation des objets composites dans les vidéos. Les méthodes de segmentation basées sur le mouvement et de suivi d'objets ont récemment fait l'objet de nombreuses publications (voir Proceedings of the Workshop on Image Analysis for multimedia Interactiv Services – WIAMIS'97, Louvain-la-Neuve, Belgique, juin 1997). Une limitation des méthodes basées principalement sur le mouvement, par rapport à notre approche basée sur les objets sémantiques, est que la méthode basée sur le mouvement n'est pas toujours applicable (objets statiques) et qu'elle ne fournit pas d'informations de structure.

Selon la présente approche, il est possible d'utiliser une représentation sur plusieurs dimensions du mouvement et de la couleur (par exemple : deux dimensions pour le mouvement, une pour le nombre de blocs pour chaque valeur des deux dimensions précédentes). Cependant dans une autre mise en œuvre utile de notre procédé, la segmentation est faite uniquement sur la couleur, la distribution du

10

15

20

25

30

mouvement est calculée sur chaque objet ou partie d'objet. Cette distribution (par exemple la moyenne et l'écart type des vecteurs de mouvement) est utilisée pour définir des objets composites à partir d'un même mouvement des différentes parties.

Les différences entre les caractéristiques de mouvement dans différentes parties d'un objet sémantique peuvent aussi être utilisées pour décrire un mouvement complexe ou une action de cet objet. Par exemple, le mouvement d'un bras dans un personnage n'est pas forcément le mouvement moyen de l'objet.

Après compensation des mouvements de caméra (travellings, zooms, ...) les informations de mouvements peuvent être utilisées de 2 façons :

- la segmentation des objets en mouvement retourne une segmentation en région qui est nécessairement un sur-ensemble de la segmentation obtenue sur les images fixes par notre algorithme. Les régions appartenant à un même objet en mouvement sont regroupées pour former un objet composite ;
- les régions obtenues par la méthode de segmentation présentée ci-dessus et présentant les mêmes caractéristiques de mouvement (vitesse, trajectoire) sur des images consécutives sont regroupées pour former un objet composite.

Si l'analyse du mouvement est importante pour l'amélioration de la segmentation en objets composites, elle n'est pas suffisante dans certains cas, notamment dans la cas de plans ou scènes relativement statiques.

Une troisième méthode basée sur la cooccurrence des régions dans les images est proposée : si la combinaison de régions, par exemple casque-visage-veste, apparaît régulièrement dans des suites de plans, alors ces régions peuvent être associées avec une probabilité importante de cooccurrence. Les objets étant représentés dans un espace des caractéristiques citées précédemment, la probabilité de cooccurrence des

20

25

30

objets sémantiques segmentés peut être calculée, par exemple par les méthodes statistiques connues utilisées pour l'indexation de documents textuels.

Enfin, les objets voisins peuvent être regroupés en objets composites à l'aide de leur valeur sémantique.

Exemple 4 : Suivi d'un objet à travers une ou plusieurs scènes

Les méthodes précédentes permettent de retrouver un même objet sémantique à travers plusieurs images successives d'une scène d'une vidéo, ou même à travers plusieurs scènes situées dans différents passages de cette vidéo. Cette caractérisation se fait à partir des méthodes de similarité entre objets ou régions visuelles décrites précédemment, et compte tenu des déplacements de l'objet : un objet semblable situé à la même place dans l'image suivante a plus de chance d'être le même objet que s'il est dans une partie opposée de l'image.

Le suivi d'objet (ou traçage d'objets) dans une vidéo est un problème connu, qui fait l'objet de plusieurs travaux d'autres auteurs. Dans notre approche, le fait de disposer d'objets sémantiques simples ou composites limite le nombre d'objets à suivre, d'autre part nous utilisons une méthode spécifique de recherche de similarité entre plusieurs occurrences d'un objet, comme nous l'avons décrit précédemment.

Dans certains cas, le suivi d'objets permet de détecter des actions. Par exemple le fait que deux objets se déplacent ensemble puis sont séparés, traduit fréquemment le fait qu'un des objets a déposé l'autre au cours de l'intervalle. Le fait qu'il s'agit d'objets sémantiques accroît la qualité de cette détection d'actions

Exemple 5 : Sélection d'objets en vue du stockage sur le système d'un utilisateur

Lors de l'accès intelligent à une base d'images, ou une grande base de vidéos, ou un ensemble de programmes audiovisuels diffusés, il est utile de pouvoir stocker une partie de cette base ou de ces

15

20

25

30

programmes intéressante pour un utilisateur, sur un système de stockage, par exemple au site de production du programme ou chez l'utilisateur.

Dans le présent procédé, les parties de la vidéo stockées sur ce système de stockage sont des intervalles temporels ou des ensembles d'images caractérisés par la présence de descripteurs de séquences ou de sujets vérifiant une requête de l'utilisateur ou du système, ou par la présence d'objets visuels ou sonores vérifiant une telle requête.

Ces parties sont stockées dans un certain ordre, qui dépend soit de la pertinence des objets trouvés, soit de règles de transition entre objets définies par le système ou par l'utilisateur, soit un ordre aléatoire. Les règles de transition peuvent être extraites à partir des associations usuelles faites par un utilisateur, ou des transitions faites usuellement par celui-ci.

La requête utilisée a pour but de retrouver un objet (ou une séquence ou un sujet) dans laquelle on retrouve avec un degré de pertinence et de réalisation plus ou moins élevé un ensemble de caractéristiques de contenu présents dans la requête ou dans un jeu d'exemples associé à la requête. Les objets ou les segments temporels recherchés peuvent être ceux pour lesquels soit l'utilisateur a manifesté un intérêt, par exemple par la consultation d'objets semblables lors de sessions antérieures, soit un utilisateur semblable a manifesté un intérêt. Deux utilisateurs sont semblables par rapport à cette application, s'ils manifestent un intérêt pour un même ensemble de documents ou d'objets audiovisuels. Dans ces deux cas, les requêtes qui serviront à sélectionner les objets ou les segments temporels peuvent être produites automatiquement par le système.

Exemple 6 : Utilisation pour un système de compression et de composition d'objets vidéo

Dans un système de compression de vidéos basé sur une représentation par objets, il est utile de pouvoir décrire une image comme

15

20

un ensemble d'objets. Un objet qui intéresse davantage un utilisateur peut être transmis avec un taux de compression plus faible qu'un autre objet (tel que l'arrière plan). D'autre part, une scène vidéo peut être éditée de façon à juxtaposer plusieurs objets provenant de scènes différentes, ou à supprimer certains objets.

Pour réaliser ces objectifs, la disposition d'une segmentation en objets sémantiques est utile. Dans notre approche, les méthodes de segmentation utilisées permettent d'accéder à une structure arborescente des objets, depuis l'intervalle temporel ou l'image, puis des objets composites, jusqu'à la structure interne de ces objets, comme nous l'avons décrit précédemment.

Cette approche permet d'appliquer les méthodes d'un système de représentation de vidéo par objets, d'une façon efficace, et avec une granularité qui varie de l'objet composite à la structure fine.

L'invention n'est pas limitée aux exemples décrits et représentés. D'autres utilisations et applications sont ci-après définies :

- utilisation selon laquelle une région à signification sémantique est également caractérisée par des régions plus petites contenues dans la première ;
- pour étiqueter les objets dans une image par une description du type et du contenu de ces objets ;
- pour détecter les objets communs dans plusieurs plans d'une vidéo, en vue de grouper ces plans en groupes de plans à signification sémantique ;
- pour détecter les suites de plans réalisés dans un même contexte, appelés scènes ou séquences, et les groupes de plans réalisés dans un même contexte, appelés groupes de plans ou clusters ;
 - l'utilisation conjointe avec la dictée vocale pour caractériser le contenu des plans et des scènes d'une vidéo :

10

15

20

- application à des images fixes et animées, conjointement avec des annotations effectuées par l'utilisateur, pour caractériser les objets de la vidéo par des caractéristiques objectives et subjectives :
- application à une base d'images, pour caractériser un objet composite pour l'association fréquente de plusieurs composantes de l'objet dans la même image;
- l'utilisation pour décrire un objet audiovisuel comportant des images, dans un format de représentation décrivant notamment la position des objets sémantiques contenus dans l'objet audiovisuel, ces objets sémantiques étant caractérisés par un ensemble de caractéristiques sémantiques;
- l'utilisation pour décrire un objet audiovisuel comportant des images, dans un format de représentation décrivant notamment les actions des objets sémantiques contenus dans l'objet audiovisuel ;
- l'utilisation pour sélectionner les objets d'un flot d'objets audiovisuels, devant être stockés dans le système de stockage d'un utilisateur de ce flot audiovisuel en vue de l'accès ultérieur à ces objets ;
- l'utilisation des procédés selon l'invention, dans lesquels le degré de vraisemblance ou de réalisation de la caractéristique est respectivement caractérisée ou représentée par un nombre.
- l'utilisation pour la compression et la transmission d'images fixes et animées avec un degré de compression variable selon l'interaction actuelle ou antérieure de l'utilisateur avec un objet sémantique donné ;
- l'utilisation pour la représentation d'images fixes et animées
 comme un ensemble d'objets sémantiques dans une scène dont la composition peut être modifiée par l'utilisateur.

10

15

20

25

REVENDICATIONS

1. Procédé de segmentation spatiale d'une image en objets visuels, caractérisé en ce que, pour obtenir des objets ayant une signification sémantique, il comporte les étapes suivantes :

- dans une première phase, une partition de l'image en régions selon un pavage prédéterminé, une fusion de régions voisines dont la similarité, selon une première fonction de similarité, est inférieure à un premier seuil, et l'obtention de régions élargies,

- dans une deuxième phase, une fusion d'une région élargie de taille inférieure à un deuxième seuil avec une région voisine qui lui est la plus similaire selon une deuxième fonction de similarité.

- 2. Procédé selon la revendication 1, caractérisé en ce qu'il comporte une troisième phase, de fusion des régions obtenues à l'issue de la deuxième phase et qui sont similaires selon une troisième fonction de similarité.
- 3. Procédé selon la revendication 1 ou 2, caractérisé en ce que les fonctions de similarité dans au moins deux des phases sont différentes.
- 4. Procédé selon l'une des revendications 1 à 3 dans lequel les régions voisines fusionnables dans l'une quelconque des phases peuvent être des régions initiales ou des régions issues d'une fusion selon une fonction de similarité différente.
 - 5. Procédé selon l'une des revendications 1 à 4, caractérisé en ce que pour une fonction de similarité on retient une méthode comportant :
- une distribution des pixels d'une région dans un espace de représentation de manière à former un nuage de points dans cet espace, chaque point de cet espace y représentant un pixel.
- cet espace de représentation comportant au moins une dimension de base relatives à des caractéristiques physiques des pixels.
- une extraction d'un ensemble de grandeurs statistiques relatives à

ce nuage, et

15

20

25

30

- la définition d'un critère de ressemblance entre ces grandeurs statistiques.
- 6. Procédé selon la revendication 4, caractérisé en ce que si l'espace comporte au moins deux dimensions,
- l'extraction des grandeurs statistiques comporte un ajustement polynomial d'une courbe avec les points du nuage d'une région, et la représentation de cet ajustement polynomial par une suite de valeurs ajustées, et
- la définition du critère de ressemblance comporte une détermination d'un troisième seuil de comparaison pour comparer de telles suites de valeurs ajustées.
 - 7. Procédé selon la revendication 6, dans lequel la fonction de similarité entre deux régions dépend de positions de centroïdes de nuages de deux régions, et d'extrémités de deux segments de courbe représentant ces deux régions.
 - 8. Procédé selon la revendication 7, dans lequel la fonction de similarité est la distance entre les centroïdes des nuages de points.
 - 9. Procédé selon l'une des revendications 6 à 8, dans lequel l'ajustement polynomial est une régression linéaire.
 - 10. Procédé selon l'une des revendications 6 à 9, dans lequel les nuages de points décrivant une région sont distribués dans un espace dont trois dimensions de base sont trois combinaisons linéaires ou non linéaires distinctes des trois couleurs primaires de la synthèse additive et une autre dimension dans cet espace étant l'effectif des pixels selon cette distribution.
 - 11. Procédé selon l'une des revendications 5 à 9, dans lequel les points d'un nuage décrivant une région sont distribués dans un espace dont trois dimensions de base sont la teinte, la saturation et l'intensité de la couleur, et une autre dimension dans cet espace étant l'effectif des

10

15

20

pixels selon cette distribution.

- 12. Procédé de segmentation selon la revendication 11 dans lequel le calcul de similarité entre régions est réalisé :
- en utilisant l'espace teinte/saturation/intensité si une saturation moyenne est supérieure à une quatrième seuil prédéterminé;
- dans l'espace des intensités, si la saturation est inférieure ou égale à ce quatrième seuil.
- 13. Procédé selon l'une quelconque des revendications 1 à 9, dans lequel le signal électromagnétique apparaissant dans au moins deux images est transformé pour en extraire pour chaque région au moins deux composantes de mouvement entre les deux images pour le représenter, telles que valeur scalaire et orientation, et où les autres étapes du procédé s'appliquent à cette représentation.
- 14. Procédé de segmentation spatiale d'une image en objets visuels, caractérisé en ce que :
 - a) au moins deux segmentations sont réalisées selon l'une des revendications 1 à 12 avec au moins deux tailles de régions initiales correspondant à des résolutions différentes ;
 - b) on superpose les objets obtenus,
- c) on remplace le contour de l'objet obtenu par la résolution la moins fine par le contour obtenu par la résolution la plus fine, et/ou
- d) l'image est représentée comme une arborescence d'objets, chaque objet de niveau supérieur pouvant inclure un ou plusieurs objets de niveau inférieur.
- 25 15. Procédé de segmentation selon l'une quelconque des revendications précédentes dans lequel les seuils prédéterminés sont choisis pour maintenir la distribution des tailles des régions dans un intervalle défini pour éviter une sur et une sous-segmentation.
- 16. Procédé selon l'une des revendications 1 à 15, dans lequel des paramètres de seuil, de degré de polynôme et de fonction de similarité

15

2.5

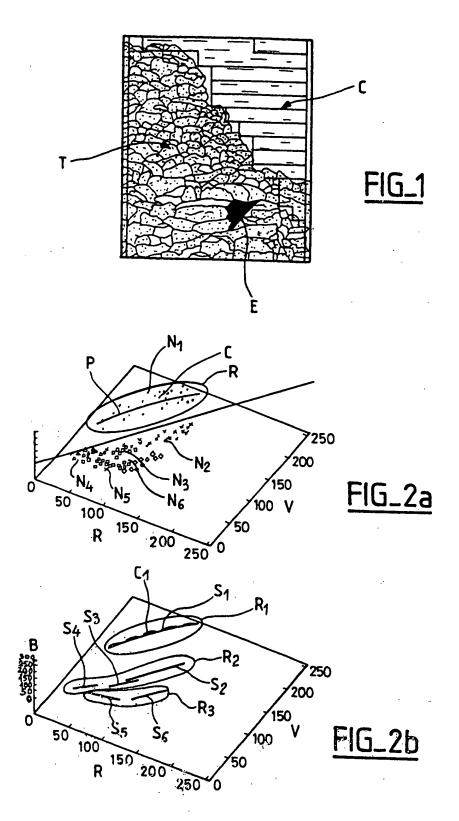
sont choisis de façon adaptative par une méthode d'apprentissage prédéterminée, en fonction de seuils de sur-segmentation et de sous-segmentation à éviter, et d'un calcul d'évaluation prédéterminé de celles-ci.

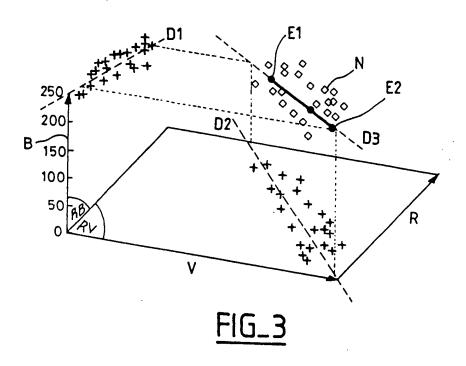
- 17. Utilisation du procédé selon l'une des revendications 1 à 16, pour caractériser l'image par un ensemble d'objets décrits par plusieurs caractéristiques, l'une au moins de ces caractéristiques étant représentées par un nombre ou par une valeur dans un ensemble énuméré.
- 18. Utilisation du procédé selon l'une des revendications 1 à 17, pour classer les objets visuels de plusieurs images segmentées à l'aide de partition de l'espace de représentation des objets par une méthode de classification avec apprentissage choisie parmi une méthode de type neuronale; une méthode de type génétique et une méthode d'analyse des données.
 - 19. Utilisation conjointe du procédé selon l'une des revendications 1 à 17 et d'une mesure de distance entre les courbes d'ajustement dans un espace de représentation de ces courbes, pour détecter la présence d'un même objet dans plusieurs images, consécutives ou non.
- 20. Utilisation conjointe du procédé selon l'une des revendications 1
 à 17 avec des méthodes statistiques de caractérisation des concepts contenus dans un texte, pour caractériser le contenu d'une suite de scènes portant sur un même sujet.
 - 21. Utilisation conjointe du procédé selon l'une des revendications 1 à 17 avec la reconnaissance d'un locuteur, pour caractériser le contenu de plans et de scènes d'une vidéo.
 - 22. Utilisation conjointe du procédé selon l'une des revendications 1 à 17 avec un alignement automatique entre un script et une vidéo, pour caractériser le contenu des plans et des scènes d'un document vidéo.
- 23. Utilisation conjointe du procédé selon l'une des revendications 1
 à 17 avec un alignement automatique entre un script et une vidéo, pour

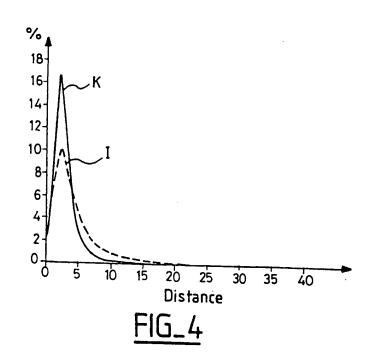
apprendre de façon automatique les caractéristiques des objets présents dans la vidéo et dans le script.

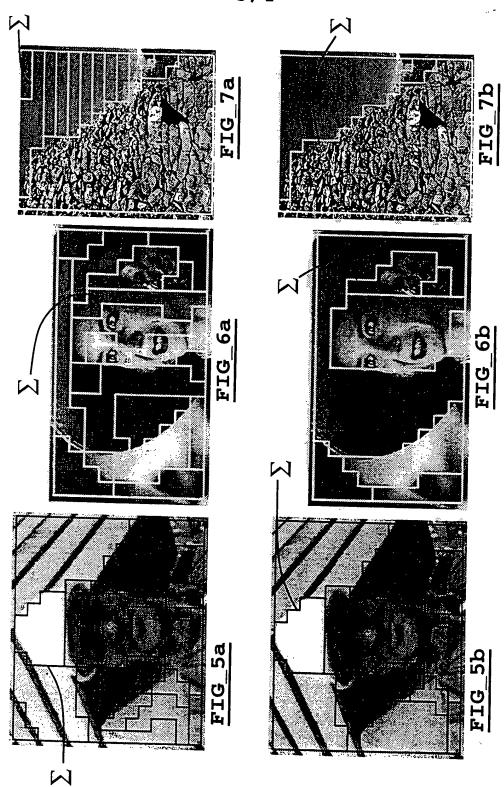
24. Utilisation conjointe du procédé selon l'une des revendications 1 à 17 avec la transcription de la parole de la vidéo sous forme de texte par une méthode de dictée vocale, pour caractériser le contenu de plans et de scènes d'une vidéo.

10

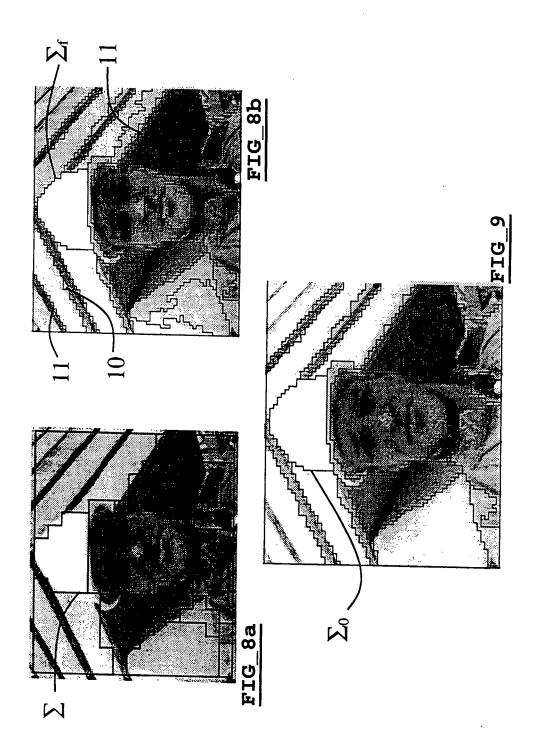








FEUILLE DE REMPLACEMENT (REGLE 26)



FEUILLE DE REMPLACEMENT (REGLE 26)

INTERNATIONAL SEARCH REPORT

Inte onal Application No PCT/FR 99/00176

A. CLASS	SIFICATION OF SUBJECT MATTER		
IPC 6	G06T5/00		
According	to International Patent Classification (IPC) or to both national class	sification and IPC	
B. FIELDS	SEARCHED		
Minimum d IPC 6	ocumentation searched (classification system followed by classifi G06T	cation symbols)	
Documenta	ation searched other than minimum documentation to the extent th	at such documents are included in the fields a	earched
Electronic o	data base consulted during the international search (name of data	base and, where practical search terms used	()
	ENTS CONSIDERED TO BE RELEVANT		,
Category *			
Category	Citation of document, with indication, where appropriate, of the	where appropriate, of the relevant passages	
Y	SCHROETER P ET AL: "Hierarchic segmentation by multi-dimension clustering and orientation-adap boundary refinement" PATTERN RECOGNITION, vol. 28, no. 5, 1 May 1995, pag XP004011495 see abstract see page 697, left-hand column, page 699, left-hand column, lin	al tive e 695-709	1-24
<u> </u>	ner documents are listed in the continuation of box C.	X Patent family members are listed in	in annex.
"A" docume	tegories of cited documents: ant defining the general state of the art which is not	T later document published after the Inte	mational filing date
considered to be of particular relevance "E" earlier document but published on or after the international		envention	ory underlying the
"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another		X document of particular relevance; the cl dannet be considered novel or cannot native an inventive step when the doc	be considered to rument is taken alone
CRETION	n or other special reason (as specified) ant referring to an oral disclosure, use, exhibition or	comment of particular relevance; the ci	
"P" docume	means ont published prior to the international filing date but an the priority date claimed	ments such combination being obvious in the art	s to a person skilled
	actual completion of the international search	3 document member of the same patent f. Oate of mailing of the international seal	_
3:	1 May 1999	09/06/1999	· ·
Name and m	nailing address of the ISA	Authorized officer	
	European Patent Office, P.B. 5818 Patentiaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Tx. 31 851 epo ni,		
	Fax: (+31-70) 340-3016	Gonzalez Ordonez.	o I

1

INTERNATIONAL SEARCH REPORT

Inte onal Application No PCT/FR 99/00176

tegory *	Citation of document, with indication, where appropriate, of the relevant passages	Ta.
		Relevant to claim No.
	LI Y ET AL: "SEMANTIC IMAGE RETRIEVAL THROUGH HUMAN SUBJECT SEGMENTATION AND CHARACTERIZATION" STORAGE AND RETRIEVAL FOR IMAGE AND VIDEO DATABASES 5, SAN JOSE, FEB. 13 - 14, 1997, no. VOL. 3022, 13 February 1997, pages 340-351, XP000742394 SETHI I K;JAIN R C (EDS) see abstract see paragraph 1 - paragraph 2	1-24
	EP 0 596 412 A (MATSUSHITA ELECTRONICS CORP) 11 May 1994 see abstract see page 4, line 54 - line 58; figures 2,3	1-25

Form PCT/ISA/210 (continuation of second sheet) (July 1992)

1

INTERNATIONAL SEARCH REPORT

information on patent family members

Int. Jones Application No PCT/FR 99/00176

Pate	nt document search report		Publication		Patent family		99/00176 -
			date		Patent family member(s)		Publication date
EP 0	596412	Α	11-05-1994	JP DE US	61500 693242 55197	07 D	31-05-1994 06-05-1999 21-05-1996
		•					
	ent (emily annex) (Ju					_	

KAI	PORT DE RECHERCHE INTERNATION	ONIATE .		
	TOTAL DE RECIERCIE INTERNATIO	UNALE	PCT/FR 99	ationale No
A. CLASS	EMENT DE L'OBJET DE LA DEMANDE		TC1/FR 95	7 001/6
CIB 6	G06T5/00			
	assification internationale des brevets (CIB) ou à la fois selon la classificatio	n nationale et la C	18	
B. DOMAI	NES SUR LESQUELS LA RECHERCHE A PORTE			
CIR 0	tion minimale consultée (système de classification suivi des symboles de c G06T			
	tion consultée autre que la documentation minimale dans la mesure où ces			
Base de do	nnées électronique consultée au cours de la recherche internationale (nom	de la base de don	nées, et si réalisai	ole, termes de recherche utilisés)
C. DOCUM	ENTS CONSIDERES COMME PERTINENTS			
Catégorie *	Identification des documents cités, avec, le cas échéant, l'indication des	Dagagaga nodlasa	· · · · · · · · · · · · · · · · · · ·	T
	The same and the s	Passages pertinen		no. des revendications visées
Y	SCHROETER P ET AL: "Hierarchical im segmentation by multi-dimensional clustering and orientation-adaptive boundary refinement" PATTERN RECOGNITION, vol. 28, no. 5, 1 mai 1995, page 695 XP004011495 voir abrégé voir page 697, colonne de gauche, li-page 699, colonne de gauche, ligne	-709 gne 25 19		1-24
	a suite du cadre C pour la fin de la liste des documents	Les documents	de familles de bre	vets sont indiqués en annexe
"A" docume conside "E" docume ou apriorité autre co" docume une ex "P" docume	ore comme particulièrement pertinent nt antérieur, male publié à la date de dépôt international es cette date nt pouvant jeter un doute sur une revendication de ou cité pour déterminer le date de publication d'une tation ou pour une raison spéciale (telle qu'indiquée) nt se référant à une divulgation orale, à un usage, à position ou tous autres moyens nt publié avant la date de dépôt international, mais	schnique pertinent, u la théorie constit cument particulière tre considérée con ventive par rappoi cument particulière e peut être conside raque le documen ocumente de mêm our une personne our une personne	appartenenant pai mais cité pour coi uant la base de l'Ir ement pertinent; l'il ime nouvelle ou ci t au document cor ement pertinent; l'il drée comme implicit est associé à un e nature, cette cor du métler	mprendre le principe ivention revendiquée ne peut principe l'impliquant une activité siddré isolément invention revendiquée quant une activité inventive ou plusieure autres nbinaison étant évidente
	ilo la costacida (como il como	cument qui fait par ate d'expédition du		nille de brevets e recherche internationale

Formulaire PCT/ISA/210 (deuxième feuille) (juillet 1992)

1

Nom et adresse postale de l'administration chargée de la recherche internationale Office Européen des Brevets, P.B. 5818 Patentiaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Tx. 31 651 epo nl, Fax: (+31-70) 340-3016

31 mai 1999

Gonzalez Ordonez, 0

09/06/1999

Fonctionnaire autorisé

RAPPORT DE RECHERCHE INTERNATIONALE

Den e internationale No PCT/FR 99/00176

Catégorie	OCUMENTS CONSIDERES COMME PERTINENTS		
oategorie 1	identification des documents cités, avec, le cas échéant, l'indicationdes passages p	ertinents	no. des revendications visées
(LI Y ET AL: "SEMANTIC IMAGE RETRIEVAL THROUGH HUMAN SUBJECT SEGMENTATION AND CHARACTERIZATION" STORAGE AND RETRIEVAL FOR IMAGE AND VIDEO DATABASES 5, SAN JOSE, FEB. 13 - 14, 1997, no. VOL. 3022, 13 février 1997, pages 340-351, XP000742394 SETHI I K;JAIN R C (EDS) voir abrégé voir alinéa 1 - alinéa 2		1-24
	EP 0 596 412 A (MATSUSHITA ELECTRONICS CORP) 11 mai 1994 voir abrégé voir page 4, ligne 54 - ligne 58; figures 2,3		1-25
			· .

RAPPORT DE RECHERCHE INTERNATIONALE

Document branch and			FR 99/00176
Document brevet cité au rapport de recherche	Date de publication	Membre(s) de la famille de brevet(s)	Date de publication
EP 0596412 A	11-05-1994	JP 6150000 A DE 69324207 D US 5519789 A	31-05-1994 06-05-1999 21-05-1996

Formulaire PCT/ISA/210 (annexe families de breveta) (juillet 1992)